

9. Ren Y., Xie X., Li G., Wang Z. Hand gesture recognition with multiscale weighted histogram of contour direction normalization for wearable applications. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, vol. 28, iss. 2, pp. 364-377. doi: 10.1109/TCSVT.2016.2608837.
10. Song H., Feng W., Guan N., Huang X., Luo Z. Towards robust ego-centric hand gesture analysis for robot control. *2016 IEEE International Conference on Signal and Image Processing (ICSIP)*, 2016, pp. 661-666. doi: 10.1109/SIPROCESS.2016.7888345.

Рецензент: О.Є. П'ятикоп
канд. техн. наук, доц., ДВНЗ «ПДТУ»

Стаття надійшла 23.08.2021

УДК 004.032.26:629.11

doi: 10.32782/2225-6733.43.2021.2

© Федосова І.В.¹, Подольніков І.В.², Гальчук Д.С.³

РОЗПІЗНАВАННЯ ДЕРЖАВНИХ НОМЕРІВ ТРАНСПОРТНИХ ЗАСОБІВ ЗА ДОПОМОГОЮ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ

Стаття розкриває тему розробки системи розпізнавання державних номерів різноманітних транспортних засобів, використовуючи сучасні підходи і алгоритми згорткових нейронних мереж. Система зосереджена на необмежених сценаріях захоплення, де державні знаки можуть бути значно спотворені через похилі види та інші недоліки цифрового зображення. Під час аналізу зовнішніх джерел було виявлено, що аналогічні системи мають безліч недоліків, які виражаються у: нестійкості розпізнавання низькоякісних зображень, погану ідентифікацію об'єктів (розпізнавання об'єктів, які не відносяться до транспортного засобу), а також жорсткому обмеженні обчислювальних потужностей та виробників відеокарт. Як наслідок було виявлено проблему, поставлено мету роботи, проаналізовано наукові дослідження та публікації, а також побудовано математичну модель, проведено навчання моделі нейронної мережі та тестування якості розпізнавання. Після розробки системи були виявлені й усунуті її недоліки та підвищена продуктивність. У підсумку отримано систему, що може використовуватись на відеоадаптерах Nvidia, але при необхідності (відеочіп Radeon або чіп, інтегрований у процесор) нейронна мережа може використовувати процесор. Також однією з основних переваг стала трьошарова робота нейронної мережі, завдяки котрій спочатку відбувається пошук транспортного засобу, після чого на вихідному зображенні проводиться пошук державного номеру і наприкінці починається розпізнавання номерного знаку. До більш непомітних, але важливих переваг, можна віднести: швидкість роботи, низькі системні вимоги, а також розпізнавання номерних знаків будь-якого формату та країни. Результати тестування показують, що запропонований метод без будь-якої адаптації параметрів та налаштувань для конкретного сценарію працює аналогічно найсучаснішим комерційним системам у традиційних сценаріях та навіть перевершує деякі із них.

Ключові слова: розпізнавання номерних знаків, нейронні мережі, глибоке навчання.

¹ д-р пед. наук, професор, ДВНЗ «Приазовський державний технічний університет», м. Маріуполь, ORCID: 0000-0003-3923-8270, irivasilevna1964@gmail.com

² магістр, ДВНЗ «Приазовський державний технічний університет», м. Маріуполь

³ студент, ДВНЗ «Приазовський державний технічний університет», м. Маріуполь

I.V. Fedosova, I.V. Podolnikov, D.V. Halchuk. Identification of vehicles registration numbers using a convolutional neural network. The article considers developing a system for identification vehicles registration numbers, using modern approaches and algorithms of convolutional neural networks. The system focuses on numerous ways of getting the images, where the state signs can be significantly distorted due to sloping views and other drawbacks of the digital image. The analysis of external sources, made it possible to find out that similar systems have many disadvantages, which result in: instability of poor-quality image identification, poor identification of objects (identification of non-vehicles), as well as strict limitation of computing power and video card manufacturers. As a result, the problem has been identified, the purpose of the work has been set, research works and publications have been analyzed, and a mathematical model has been worked out, it being one of the initial stages of the development. The next step was to train the neural network model, after which the stage of testing the quality of identification began. After developing the system, its drawbacks were identified and eliminated and its productivity increased. As a result, a system was got that can be used on Nvidia video adapters, but if necessary (Radeon video chip, or chip integrated into the processor) the neural network can use the processor. Also, one of the main advantages was the three-layer operation of the neural network, thanks to which, first the vehicle is searched, then the outlet image is searched for the state number, and finally the license plate identification begins. Among the more subtle but important advantages are: the rate of the work, low system requirements, as well as license plate of any format and country identification. The test results show that the proposed method without any adaptation of parameters and settings for that very case works similarly to the most modern commercial traditional systems and even surpasses some of them.

Key words: license plate identification, neural networks, deep studying.

Постановка проблеми. Окремі програми, що пов'язані з дорожнім рухом, такі як виявлення вкрадених транспортних засобів, контроль над зборами та перевірка доступу до автостоянки, включають ідентифікацію транспортного засобу, яка виконується системами автоматичного розпізнавання номерних знаків (АРНЗ). Нещодавні досягнення в галузі паралельної обробки та глибокого навчання (ГН) сприяли покращенню багатьох завдань комп'ютерного зору, таких як виявлення/розпізнавання об'єктів та оптичне розпізнавання символів (ОРС), яке приносить користь системам АРНЗ. Насправді глибокі згорткові нейромережі (ГЗН) були провідною технологією машинного навчання, що застосовується для виявлення транспортних засобів та номерних знаків (НЗ) [1-3]. Поряд з науковими роботами, кілька комерційних систем АРНЗ також досліджують методи ГН. Зазвичай вони розміщуються у величезних центрах обробки даних і працюють за допомогою веб-сервісів, здатних обробляти від тисячі до мільйонів зображень на день і постійно вдосконалюватися.

Незважаючи на прогрес сучасного рівня, більшість систем АРНЗ передбачають переважно фронтальний вигляд транспортного засобу та номерного знаку (НЗ), що є поширеним у таких додатках, як моніторинг плати за збори та перевірка стоянок. Однак більш спокійні сценарії зйомки зображень (наприклад, співробітник правоохоронних органів, що йде з мобільною камерою або смартфоном) можуть призвести до поганих результатів, у яких НЗ можуть бути сильно спотвореними.

У роботі запропонована повна система АРНЗ, яка добре працює у різних сценаріях та налаштуваннях камери.

Мета роботи – впровадження нової нейронної мережі, здатної виявляти НЗ у багатьох різних позах камери та оцінювати її спотворення, дозволяючи процес виправлення перед ОРС. Додатковою метою є масове використання синтетично деформованих версій реальних зображень для розширення навчального набору даних, що дозволяє тренувати мережу з нуля, використовуючи менше 300 зображень з маркуванням вручну. Запропонована схема збільшення мережі та даних призвела до гнучкої системи АРНЗ, яка змогла успішно виявляти та розпізнавати НЗ у незалежних наборах даних тестування, використовуючи ту саму параметризацію системи.

Аналіз останніх досліджень і публікацій. Успіх мереж YOLO [4] надихнув багато останніх робіт, спрямованих на продуктивність у режимі реального часу для виявлення НЗ [3].

Дещо змінена версія мереж YOLO та YOLOv2 [5] була використана Hsu та співавторами, де автори збільшили деталізацію вихідних даних мереж, щоб покращити кількість виявлень, і встановили ймовірності для двох класів (НЗ та фонового). Їхня мережа досягла хорошого компромісу між точністю та відкликанням, але в документі бракує детальної оцінки вилучених обмежувальних рам (bounding boxes). Більше того, відомо, що мережі YOLO намагаються виявити об'єкти невеликого розміру, тому потрібні подальші оцінки сценаріїв, коли транспортний засіб знаходиться далеко від камери.

У статті [3] було навчено налаштування двох мереж на основі YOLO з метою виявлення НЗ. Перша мережа використовується для пошуку області, що містить НЗ, що називається «модель уваги (attention model)», а друга мережа фіксує оберт прямокутної обмежувальної рамки НЗ. Тим не менш, вони враховували лише обертання на площині, а не більш складні деформації, спричинені косими видами камери. Крім того, оскільки вони не мають повної системи АРНЗ, важко оцінити, наскільки добре метод розпізнавання тексту буде працювати на виявлених регіонах.

Детектори номерних знаків, які використовують підсувні вікна або фільтрування кандидатів у поєднанні з ГЗН, також можна знайти у джерелах [1, 2, 6]. Однак вони, як правило, є неефективними в обчисленні внаслідок нерозподілу обчислень, як у сучасних мета-архітектурах для виявлення об'єктів, таких як YOLO, SSD [7] та Faster R-ГЗН [8]. Хоча методи Scene Text Spotting (STS) зосереджені переважно на великих варіантах шрифту та лексичній/семантичній інформації, але варто згадати деякі підходи, які стосуються повороту/спотворення тексту та можуть бути досліджені для виявлення НЗ у косих видах. Макс Джадерберг (Max Jaderberg) та його колеги представили підхід на основі ГЗН для розпізнавання тексту в природних сценах з використанням повністю синтетичного набору даних для навчання моделі. Незважаючи на хороші результати, вони сильно покладаються на N-грами, які не застосовуються до АРНЗ. Анкуш Гупта (Ankush Gupta) також досліджував синтетичний набір даних, реалістично вставляючи текст у реальні зображення, зосереджуючись переважно на локалізації тексту. Вихідні дані являють собою поворотне обмежувальне поле з текстом, яке знаходить обмеження для обертання поза площиною, поширених у сценаріях АРНЗ. Зовсім недавно Фенг Ванг (Feng Wang) представив підхід до виявлення тексту в різних геометричних положеннях, який називається мережею трансформації екземплярів (MTE).

В основному це композиція з трьох ГЗН: магістральної мережі для обчислення функцій, мережі трансформації для визначення афінних параметрів, де нібито існує текст на карті ознак, та остаточної класифікаційної мережі, вхід якої побудований шляхом вибірки об'єктів відповідно до афінних параметрів. Хоча цей підхід (теоретично) може обробляти обертання поза площиною, він не може правильно зробити висновок про перетворення, яке насправді відображає область тексту на прямокутнику, оскільки навколо тексту немає фізичної (або чіткої фізіологічної) обмежувальної області.

В АРНЗ НЗ є прямокутним та плоским за конструкцією, і ця інформація була досліджена, щоб регресувати параметри перетворення.

Виклад основного матеріалу. Оскільки транспортні засоби є одним із основних об'єктів, присутніх у багатьох класичних наборах даних виявлення та розпізнавання, таких як PASCAL-VOC, ImageNet та COCO, було вирішено не навчати детектор з нуля (хоча така можливість присутня), і замість цього вибрано відому модель для виявлення автомобіля з урахуванням кількох критеріїв. З одного боку, бажаний високий коефіцієнт відкликання, оскільки будь-який пропущений транспортний засіб, із видимим НЗ, веде безпосередньо до загального виявлення пропусків НЗ. З іншого боку, висока точність також бажана, щоб тримати час роботи низьким, оскільки кожен помилково виявлений транспортний засіб повинен бути перевірений WPOD-NET. Виходячи з цих міркувань, вирішено використовувати мережу YOLOv2 через її швидке виконання (близько 70 кадрів в секунду), хорошу точність та компроміс при відкликанні (76,8% mAP над набором даних PASCAL-VOC). Нами внесені деякі зміни та вдосконалення у YOLOv2, підвищено продуктивність (за зразками YOLOv5), а також додано можливість обробляти зображення за допомогою процесору комп'ютера, об'єднуючи виходи, пов'язані з транспортними засобами, та ігноруючи інші класи.

Потім правильні виявлення змінюються, перш ніж подавати їх у WPOD-NET. Як емпіричне правило, більші вхідні зображення дозволяють виявляти менші об'єкти, але збільшують

обчислювальну вартість. Приблизно у фронтальному/задньому видах співвідношення між розміром НЗ та обмежувальною рамкою автомобіля (ВВ) є високим. Однак це співвідношення має тенденцію бути набагато меншим для косих/бічних оглядів, оскільки транспортний засіб ВВ має тенденцію бути більшим і більш витягнутим. Тому слід змінити розмір косих поглядів до більшого розміру, ніж фронтальні, щоб область НЗ залишалася впізнаваною.

Хоча для визначення масштабу зміни розміру можуть бути використані методи оцінки 3D-пози, такі як [5], ця робота представляє просту та швидку процедуру, засновану на співвідношенні сторін автомобіля ВВ. Коли коефіцієнт близький до одиниці, можна використовувати менший розмір, і його потрібно збільшувати у міру збільшення співвідношення сторін. Точніше, коефіцієнт зміни розміру f_{sc} задається через (1):

$$f_{sc} = \frac{1}{\min(W_v, H_v)} \min \left\{ D_{min} \frac{\max(W_v, H_v)}{\min(W_v, H_v)}, D_{max} \right\}, \quad (1)$$

де W_v та H_v – ширина та висота автомобіля ВВ, відповідно. Зауважимо, що $D_{min} \leq f_{sc} \min(W_v, H_v) \leq D_{max}$, так що D_{min} та D_{max} розмежують діапазон найменшого розміру зміненого ВВ. На основі експериментів і намагаючись зберегти хороший компроміс між точністю та часом роботи, обрано $D_{min} = 288$ та $D_{max} = 608$.

Номерні знаки – це прямокутні та плоскі об’єкти, які кріпляться до транспортних засобів для ідентифікації. Щоб скористатися його формою, авторами запропоновано новий ГЗН під назвою Мережа виявлення деформованих плоских об’єктів (WPOD-NET). Ця мережа вчиться виявляти НЗ у безлічі різних спотворень і регресує коефіцієнти афінної трансформації, що «розкриває» спотворений НЗ у форму прямокутника, що нагадує вид спереду. Хоча замість афінного перетворення можна вивчити площину перспективної проекції, поділ, що бере участь у перетворенні перспективи, може генерувати невеликі значення у знаменнику, а отже, призвести до числових нестабільностей.

WPOD-NET був розроблений за допомогою аналітичних даних YOLO, SSD та просторових трансформаторних мереж (STN). YOLO та SSD виконують швидке виявлення та розпізнавання кількох об’єктів одночасно, але вони не враховують просторові перетворення, генеруючи лише прямокутні обмежувальні рамки для кожного виявлення. Навпаки, STN може бути використаний для виявлення непрямокутних областей, проте він не може обробляти кілька перетворень одночасно, виконуючи лише одне просторове перетворення на вході.

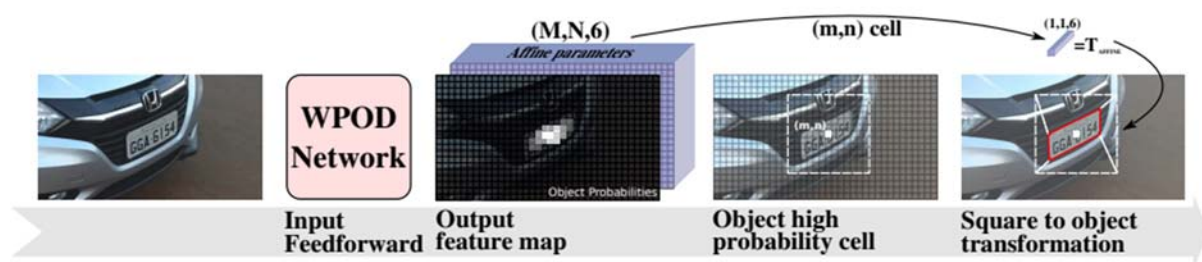


Рис. 1 – Згорткові виявлення плоских об’єктів

Процес виявлення за допомогою WPOD-NET проілюстрований на рис. 1: спочатку мережа живиться від виходу зміненого розміру модуля виявлення транспортного засобу. Передача результатів дає 8-канальну карту функцій, яка кодує об’єктні/необ’єктні ймовірності та параметри афінної трансформації. Щоб витягнути деформований НЗ, спочатку розглянемо уявний квадрат фіксованого розміру навколо центру комірки (m, n) . Якщо ймовірність об’єкта для цієї рамки перевищує заданий поріг виявлення, частина регресованих параметрів використовується для побудови афінної матриці, яка перетворює вигаданий квадрат в область НЗ. Таким чином, можливо легко перевернути НЗ в горизонтально і вертикально вирівняний об’єкт.

Пропонована архітектура має в цілому 21 згортковий шар, де 14 знаходяться всередині залишкових блоків [8]. Розмір усіх згорткових фільтрів фіксується в 3×3 . Активації ReLU використовуються по всій мережі, за винятком блоку виявлення. Існує максимально 4 шари об’єд-

нання розміром 2×2 та кроком 2, що зменшує вхідну розмірність у 16 разів. Нарешті, блок виявлення має два паралельних згорткових шари: (i) один для визначення імовірності, активований функцією softmax, та (ii) інший для регресування афінних параметрів без активації (або, що еквівалентно, з використанням ідентичності $F(x) = x$ як функції активації). Архітектуру розробленої нейронної мережі наведено на рис. 2.

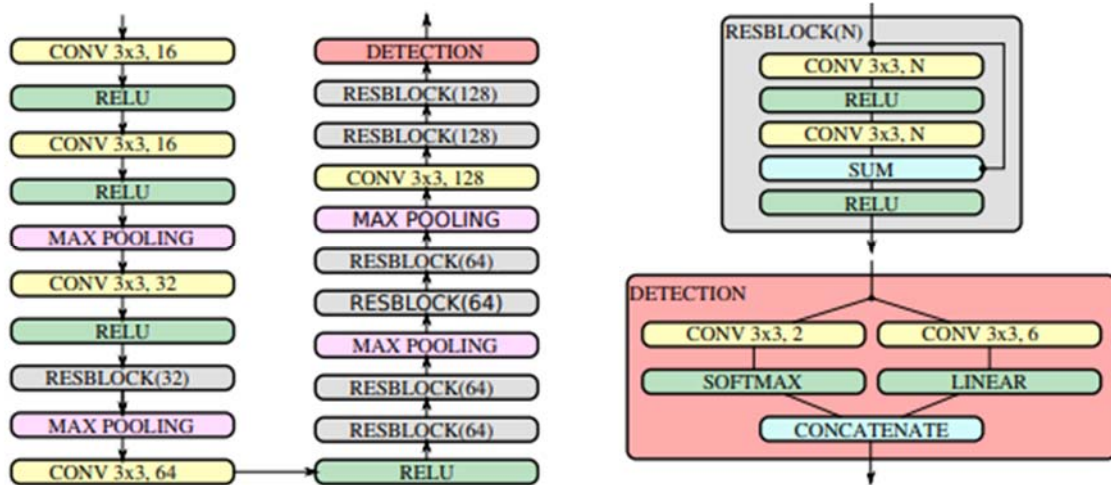


Рис. 2 – Детальна архітектура WPOD-NET

Функція втрати: нехай $p_i = [x_i, y_i]^T$, для $i = 1, \dots, 4$, позначимо чотири кути анотованого НЗ, починаючи за годинниковою стрілкою, зліва зверху. Нехай також $q_1 = [-0.5, -0.5]^T$, $q_2 = [-0.5, -0.5]^T$, $q_3 = [-0.5, -0.5]^T$, $q_4 = [-0.5, -0.5]^T$ позначимо відповідні вершини канонічного одиничного квадрата з центром у початку координат.

Для вхідного зображення висотою H і шириною W і кроком мережі, заданим $N_s = 24$ (чотири максимальні шари об'єднання), карта функцій мережевого виводу складається з тому $M \times N \times 8$, де $M = H/N_s$ і $N = W/N_s$. Для кожної клітинки точки (m, n) на карті ознак потрібно оцінити вісім значень: перші два значення (v_1 і v_2) – це ймовірності об'єкта/не об'єкта, а останні шість значень (v_3 і v_8) використовуються для побудови локального афінного перетворення T_{mn} , заданого (2):

$$T_{mn}(q) = \begin{bmatrix} \max(v_3, 0) & v_4 \\ v_5 & \max(v_6, 0) \end{bmatrix} q + \begin{bmatrix} v_7 \\ v_8 \end{bmatrix}, \quad (2)$$

де функція \max , що використовується для v_3 та v_6 , була прийнята для забезпечення позитивної діагоналі (уникнення небажаного дзеркального відображення або надмірного обернення).

Щоб відповідати дозволу вихідного сигналу мережі, точки p_i повторно масштабуються відповідно до оберненого кроку мережі та перецентруються відповідно до кожної точки (m, n) на карті об'єктів. Це досягається застосуванням функції нормалізації (3):

$$A_{mn}(p) = \frac{1}{\alpha} \left(\frac{1}{N_s} p - \begin{bmatrix} n \\ m \end{bmatrix} \right), \quad (3)$$

де α – константа масштабування, що представляє сторону вигаданого квадрата. Нами встановлено $\alpha = 7.75$, що є середньою точкою між максимальним і мінімальним розмірами НЗ у розширених даних навчання, поділених на крок мережі.

Якщо припустити, що в клітинці (m, n) є об'єкт (НЗ), перша частина функції втрати враховує помилку між деформованою версією канонічного квадрата та нормалізованими коментованими точками НЗ, заданою формулою (4):

$$f_{affine}(m, n) = \sum_{i=1}^4 \|T_{mn}(q_i) - A_{mn}(p_i)\|_1. \quad (4)$$

Друга частина функції втрат обробляє ймовірність того, що є об'єкт у (m, n) . Він подібний до втрати впевненості SSD [14] і в основному є сумою двох функцій втрати (5):

$$f_{probs}(m, n) = \text{logloss}(I_{obj}, v_1) + \text{logloss}(1 - I_{obj}, v_2), \quad (5)$$

де I_{obj} – функція індикатора об'єкта, яка повертає 1, якщо об'єкт знаходиться в точці (m, n) або 0 в іншому випадку, і $\text{logloss}(y, p) = -y \log(p)$. Об'єкт вважається всередині точки (m, n) , якщо його прямокутна обмежувальна рамка представляє IoU більше, ніж поріг γ_{obj} (емпірично встановлено 0,3), інша обмежувальна рамка такого ж розміру з центром у (m, n) . Кінцева функція втрат задається комбінацією термінів, визначених у рівняннях (4) та (5), через що отримуємо нову формулу (6):

$$\text{loss} = \sum_{m=1}^M \sum_{n=1}^N [I_{obj} f_{affine}(m, n) + f_{probs}(m, n)]. \quad (6)$$

Деталі навчання. Для підготовки запропонованого WPOD-NET створено набір даних із 196 зображень: 105 з набору даних про автомобілі, 40 з набору даних SSIG (підмножина навчальних занять) та 51 із набору даних АОНЗ (підмножина LE). Для кожного зображення вручну анотовано 4 кути номерів на зображенні (іноді більше одного). Обрані зображення з набору даних про автомобілі включають переважно європейські номери, але є багато зображень із США і України, а також інших типів пластинок. Зображення з SSIG та АОНЗ містять номери інших країн, відповідно. Кілька анотованих зразків показано на рис. 3.



Рис. 3 – Приклади анотованих НЗ у навчальному наборі даних

Висновки

У роботі представлено повну систему глибокого вивчення АРНЗ для необмежених сценаріїв. Результати показують, що запропонований підхід набагато перевершує існуючі методи у складних наборах даних, що містять НЗ, зняті під сильно скошеними оглядами, зберігають хороші результати в більш контрольованих наборах даних.

Основна поставлена мета досягнута і внеском є впровадження нової мережі, яка дозволяє виявляти та деформувати спотворені НЗ, генеруючи матрицю афінної трансформації на осередку виявлення. Цей крок полегшує навантаження на мережу розпізнавання, оскільки вона була необхідною для зменшення спотворень.

Як додатковий внесок, представлено новий складний набір даних для оцінки систем АРНЗ на знімках із переважно косими номерами.

Для майбутньої роботи можливо розширити представлене авторами рішення для виявлення номерів мотоциклів. Це створює нові проблеми через відмінності у співвідношенні сторін та макетів. Крім того, є наміри дослідити отримані афінні перетворення для автоматичного калібрування камери в сценаріях спостереження за дорожнім рухом.

Перелік використаних джерел:

1. License Plate Recognition From Still Images and Video Sequences: A Survey / C.N. Anagnostopoulos, I. Anagnostopoulos, I. Psoroulas, V. Loumos, E. Kayafas // IEEE Transactions on Intel-

- ligent Transportation Systems. – 2018. – Vol. 16(3). – Pp. 377-391. – Mode of access: <https://doi.org/10.1109/TITS.2008.922938>.
2. Segmentation and Annotation Free License Plate Recognition With Deep Localization and Failure Identification / O. Bulan, V. Kozitsky, P. Ramesh, M. Shreve // *IEEE Transactions on Intelligent Transportation Systems*. – 2017 – Vol. 18(9). – Pp. 2351-2363. – Mode of access: <https://doi.org/10.1109/TITS.2016.2639020>.
 3. Vehicle license plate recognition based on extremal regions and restricted boltzmann machines / C. Gou, K. Wang, Y. Yao, Z. Li // *IEEE Transactions on Intelligent Transportation Systems*. – 2016. – Vol. 17. – Pp. 1096-1107. – Mode of access: <https://doi.org/10.1109/TITS.2015.2496545>.
 4. Kingma D.P. Adam: A method for stochastic optimization / D.P. Kingma, J. Ba // *3rd International Conference for Learning Representations*. – 2016. – Pp. 12-15.
 5. Panahi R. Accurate detection and recognition of dirty vehicle plate numbers for high-speed applications / R. Panahi, I. Gholampour // *IEEE Transactions on Intelligent Transportation Systems*. – 2016. – Vol. 18, no. 4. – Pp. 767-779. – Mode of access: <https://doi.org/10.1109/TITS.2016.2586520>.
 6. A robust and efficient approach to license plate detection / Y. Yuan, W. Zou, Y. Zhao, X. Wang, X. Hu, N. Komodakis // *IEEE Transactions on Image Processing*. – 2017. – Vol. 26, no. 3. – Pp. 1102-1114. – Mode of access: <https://doi.org/10.1109/TIP.2016.2631901>.
 7. Spatial transformer networks / M. Jaderberg, K. Simonyan, A. Zisserman, K. Kavukcuoglu // *Advances in Neural Information Processing Systems*. – 2016. – Vol. 28. – Pp. 1-9.
 8. A robust real-time automatic license plate recognition based on the YOLO detector / R. Laroca, E. Severo, L.A. Zanolensi, L.S. Oliveira, G.R. Gonçalves, W.R. Schwartz, D. Menotti // *International Joint Conference on Neural Networks (IJCNN)*. – 2018. – Pp. 1-10. – Mode of access: <https://doi.org/10.1109/IJCNN.2018.8489629>.

References:

1. Anagnostopoulos C.N., Anagnostopoulos I., Psoroulas I., Loumos V., Kayafas E. License Plate Recognition From Still Images and Video Sequences: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 2018, vol. 16(3), pp. 377-391. doi: 10.1109/TITS.2008.922938.
2. Bulan O., Kozitsky V., Ramesh P., Shreve M. Segmentation and Annotation Free License Plate Recognition With Deep Localization and Failure Identification. *IEEE Transactions on Intelligent Transportation Systems*, 2017, vol. 18(9), pp. 2351-2363. doi: 10.1109/TITS.2016.2639020.
3. Gou C., Wang K., Yao Y., Li Z. Vehicle license plate recognition based on extremal regions and restricted boltzmann machines. *IEEE Transactions on Intelligent Transportation Systems*, 2016, vol. 17, pp. 1096-1107. doi: 10.1109/TITS.2015.2496545.
4. Kingma D.P., Ba J. Adam: A method for stochastic optimization. *3rd International Conference for Learning Representations*, 2016, pp. 12-15.
5. Panahi R., Gholampour I. Accurate detection and recognition of dirty vehicle plate numbers for high-speed applications. *IEEE Transactions on Intelligent Transportation Systems*, 2017, vol. 18, no. 4, pp. 767-779. doi: 10.1109/TITS.2016.2586520.
6. Yuan Y., Zou W., Zhao Y., Wang X., Hu X., Komodakis N. A robust and efficient approach to license plate detection. *IEEE Transactions on Image Processing*, 2017, vol. 26, no. 3, pp. 1102-1114. doi: 10.1109/TIP.2016.2631901.
7. Jaderberg M., Simonyan K., Zisserman A., Kavukcuoglu K. Spatial transformer networks. *Advances in Neural Information Processing Systems*, 2016, vol. 28, pp. 1-9.
8. Laroca R., Severo E., Zanolensi L.A., Oliveira L.S., Gonçalves G.R., Schwartz W.R., Menotti D. A robust real-time automatic license plate recognition based on the YOLO detector. *International Joint Conference on Neural Networks (IJCNN)*, 2018, pp. 1-10. doi: 10.1109/IJCNN.2018.8489629.

Рецензент: О.Є. П'ятикоп
канд. техн. наук, доц., ДВНЗ «ПДТУ»

Стаття надійшла 14.11.2021